

Методика применения аппарата нейронных сетей для решения задач диагностики процесса резания

The method of application of artificial neural networks for solving the problems of diagnosis of the cutting process

В статье предлагается новая методика использования аппарата нейронных сетей при решении задач диагностики процесса резания. Предлагается использование нейронной сети с особой коммутаторной доменной архитектурой, которая позволяет разбивать сеть на отдельные взаимосвязанные фрагменты. Фрагментированная сеть обладает высокой масштабируемостью и позволяет более эффективно применять для обучения генетические алгоритмы.

New method using artificial neural networks for solving the problems of diagnostics of the cutting process is proposed. It is proposed to use artificial neural network with a special commutator domain architecture, which allows you to break the artificial neural network into separate interconnected parts. Fragmented artificial neural network is highly scalable and allows for more effective use of genetic algorithms for learning.

Ключевые слова: нейронные сети, генетические алгоритмы, диагностика, процесс резания.

Keywords: artificial neural networks, genetic algorithms, diagnostics, cutting process.

Развитие средств диагностики процесса резания, позволяющих обеспечить его надежность и улучшить качество обрабатываемых деталей, при максимальном использовании ресурса режущего инструмента, является в настоящее время актуальной задачей [1-3]. Оптимизировать параметры возможно путем получения оперативной информации о текущем состоянии инструмента и динамике развития его износа [4].

Процесс резания имеет нелинейный характер, вследствие неоднородности начальных свойств материалов заготовки и инструмента и нестационарности параметров, его характеризующих [5]. Контроль состояния режущего инструмента трудно осуществлять прямыми методами. Поэтому определение износа инструмента осуществляют путем измерения косвенных параметров, имеющих корреляцию с износом. Эффективность диагностики процесса резания определяется информативностью анализируемых косвенных диагностических параметров и спо-

собностью алгоритма их обработки учитывать нелинейность процесса резания.

В [6] показаны основные физические явления в процессе резания, измеряемые при помощи датчиков величины, параметры сигнала, которые могут выступать в качестве косвенных диагностических параметров, и возможное применение этих параметров для определения результатов обработки резанием (табл. 1).

Анализ методов построения систем диагностики выявил тот факт, что выбор косвенных диагностических параметров, которые наиболее точно описывали бы характер износа инструмента, является одной из главных проблем при создании алгоритмов диагностики. Это приводит к тому, что алгоритм диагностики состояния режущего инструмента сильно зависит от свойств косвенного диагностического признака [7, 8, 9, 10], каждый из которых имеет свои недостатки и ограниченность применения. Поэтому более эффективным будет анализ нескольких, различных по типу,

1. Сигналы в процессе резания

Явление	Параметр сигнала	Контролируемый параметр
Сила резания	Величина сигнала, изменение во времени, амплитуда сигнала	Износ и поломки инструмента, качество и форма поверхности
Крутящий момент на шпинделе	Величина сигнала, изменение во времени	Износ и внезапные поломки инструмента
Температура в зоне резания	Величина сигнала	Износ и внезапные поломки инструмента, качество поверхности
Вибрации, акустические сигналы	Длина, частота, период колебания, скорость волны, спектр, интенсивность	Качество поверхности, износ инструмента




Рис. 1. Представление нейронной сети в традиционном виде

косвенных параметров [8, 9, 10]. Так, в [10] мониторинг и прогнозирование износа режущего инструмента производится на основании анализа сигнала виброакустической эмиссии и электропроводности контакта «инструмент - деталь».

В настоящей статье предлагается метод построения системы диагностики на базе одной нейронной сети. Изначально она представляет собой многослойную нейронную сеть (рис. 1), состоящую из n слоев: входного слоя, выходного слоя и $(k-2)$ скрытых слоев. Значения весовых коэффициентов связей между нейронными устанавливаются малыми случайными величинами с равномерным распределением в заданном диапазоне изменения. Выходным значением нейронной сети Y будет значение контролируемого диагностического параметра или его прогноз. В качестве входных значений могут выступать все возможные косвенные диагностические параметры $X = \{X_1, X_2, \dots, X_L\}$, извлекаемые из зоны резания, а также другие факторы, такие как материалы детали и режущего инструмента, покрытие режущего инструмента и его геометрия, характеристики смазывающе-охлаждающей жидкости и другие.

На первом этапе производится первичное обучение нейронной сети с помощью метода обратного распространения ошибки, целью которого является формирование начальной общей матрицы весовых коэффициентов, на основе которой выполняется фрагментация сети и последующее ее обучение с помощью генетических алгоритмов. Первичное обучение осуществляется до тех пор, пока значение целевой функции ошибки E не будет меньше заданного допустимого значения E_0 . Так как это первичное обучение, то значение E_0 выбирается достаточно большим.

Далее происходит выделение фрагментов нейронной сети – доменов [11], по алгоритму, предложенному в [12]. Данный алгоритм осуществляет рациональную группировку нейронов путем введения импульсов притяжения и отталкивания между нейронами, пропорциональных коэффициентам связей. Ввиду того, что нейроны входного слоя не связаны между

собой, то в итоге после фрагментации нейронной сети и приведения её к доменной архитектуре, многослойную нейронную сеть можно представить в виде полностью связанной сети доменов, представленной на рис. 2. При этом, каждый домен рассматривается как отдельный нейрон со сложной структурой в виде фрагмента нейронной сети.

Домены можно разделить на две группы: один домен A , непосредственно решающий задачу определения контролируемого параметра Y , и L доменов $B = \{B_1, B_2, \dots, B_L\}$, решающих задачи обработки входных параметров $X = \{X_1, X_2, \dots, X_L\}$.

Весовые коэффициенты связей нейронов, находящихся в разных доменах, будут иметь малые значения, и их можно будет заменить усредненными весовыми коэффициентами

$$z_{i,j} = \frac{1}{S} \sum_{l=1}^L \sum_{k=1}^L w_{l,k} \quad (1)$$

где S – число ненулевых весовых коэффициентов связи между нейронами доменов i и j . При этом нейрон с номером l находится в домене i , а нейрон с номером k находится в домене j .




Рис. 2. Описание структуры нейронной сети в доменном представлении




Рис. 3. Описание структуры нейронной сети в доменном представлении после оптимизации

Учитывая, что домен A не должен оказывать влияние на другие домены, а домены $B = \{B_1, B_2, \dots, B_L\}$ не должны указывать влияние на работу друг друга, то эти связи можно не учитывать в дальнейшем.

Таким образом, получаем следующую матрицу связей между доменами Z :

$$Z = \begin{pmatrix} z_1 \\ z_2 \\ z_3 \\ \vdots \\ z_L \end{pmatrix}, \quad (2)$$

где z_i – коэффициент связи домена B_i с доменом A .

В итоге нейронная сеть преобразуется в слоистую сеть доменов нейронной сети без скрытых слоев (рис. 3).

В связи с тем, что нейронная сеть не будет иметь явной слоистой структуры, дополнительное обучение предлагается проводить при помощи генетических алгоритмов. При этом обучение разбивается на L этапов, на каждом из которых хромосомы генетического алгоритма имеют разную структуру. Изменения структур хромосом показано на рис. 4.

Хромосома на каждом этапе состоит из значений элементов матриц весовых коэффициентов $\{w_1^A, w_2^A, \dots, w_q^A\}$ домена A и $\{w_1^i, w_2^i, \dots, w_g^i\}$ домена обучаемого B_i , и весовых коэффициентов связи между доменами $\{z_1, z_2, \dots, z_L\}$, добавляемых на каждом этапе.

Результатом каждого этапа будет обученный домен B_i . На следующих этапах будет только переопределяться значимость влияния выходной информации доменов, обученных на предыдущих этапах, на общий результат путем корректировки соответствующего весового коэффициента матрицы связей между доменами Z и дообучения домена A .

В случае если z_i меньше заданного значения, то можно сказать, что i -й диагностический признак не-

существенен и его можно будет удалить из сети. При этом нужно будет переобучить нейронную сеть, когда хромосома состоит из всех элементов матриц $\{z_1, z_2, \dots, z_L\}$, за исключением удаляемого z_i , и $\{w_1^A, w_2^A, \dots, w_q^A\}$ домена A . Таким образом, полностью исключается влияние удаляемого диагностического признака на результат работы сети.

Если возникнет необходимость анализа новых диагностических признаков, то добавляется M новых доменов $\{B_{L+1}, B_{L+2}, \dots, B_{L+M}\}$. Обучение производится аналогично, а алгоритм изменения структур хромосом продолжается с $(L+1)$ этапа.

Трудоёмкость обучения при помощи метода обратного распространения ошибки составляет $f(n) = O(n) \cdot N$, где n – количество нейронов в сети; N – размер обучающей выборки.

Трудоёмкость генетического алгоритма составляет $f(m) = O(m^k)$; m – длина хромосомы; k – коэффициент, зависящий от размера популяции и вероятностей генетических операторов. Соответственно трудоёмкость обучения при помощи генетических алгоритмов нейронной сети целиком будет составлять $f(n) = O(n^k) \cdot N$.

Трудоёмкость обучения фрагментированной сети при помощи генетических алгоритмов равна

$$f(n) = \left(O\left(1 + \frac{2 \cdot n}{L}\right)^k \right) + O\left(2 + \frac{2 \cdot n}{L}\right)^k + \dots + O\left(L + \frac{2 \cdot n}{L}\right)^k \cdot N = O\left(\frac{n}{L}\right)^k \cdot N \quad (3)$$

Соответственно при анализе большого количества входных параметров и эффективной работе генетических операторов предложенный алгоритм дает существенный выигрыш в оценке трудоёмкости.

Предложенная методика применения нейронных сетей для решения задач технической диагностики процесса резания позволяет на основе анализа множества диагностических параметров осуществить более достоверную диагностику. Предложенный алгоритм обучения позволяет добавлять и удалять диагностические параметры без переобучения всей нейронной сети.

Библиографический список

1. Черпаков Б.И., Григорьев С.Н. Тенденции развития технологического оборудования в начале XXI века // Ремонт, восстановление, модернизация. 2003. № 10. С. 2-7.
2. Григорьев С.Н. Тенденции и проблемы модернизации машиностроительного производства на базе отечественного станкостроения // Вестник МГТУ «Станкин». 2010. № 3. С. 7-13.
3. Мартинов Г.М. Тенденции развития современных систем управления технологическим оборудованием // Приводная техника. 2008. № 5. С. 64-66.
4. Козочкин М.П., Сабиров Ф.С. Оперативная диагностика при металлообработке - проблемы и задачи // Вестник МГТУ «Станкин». 2008. № 3. С. 14-18.

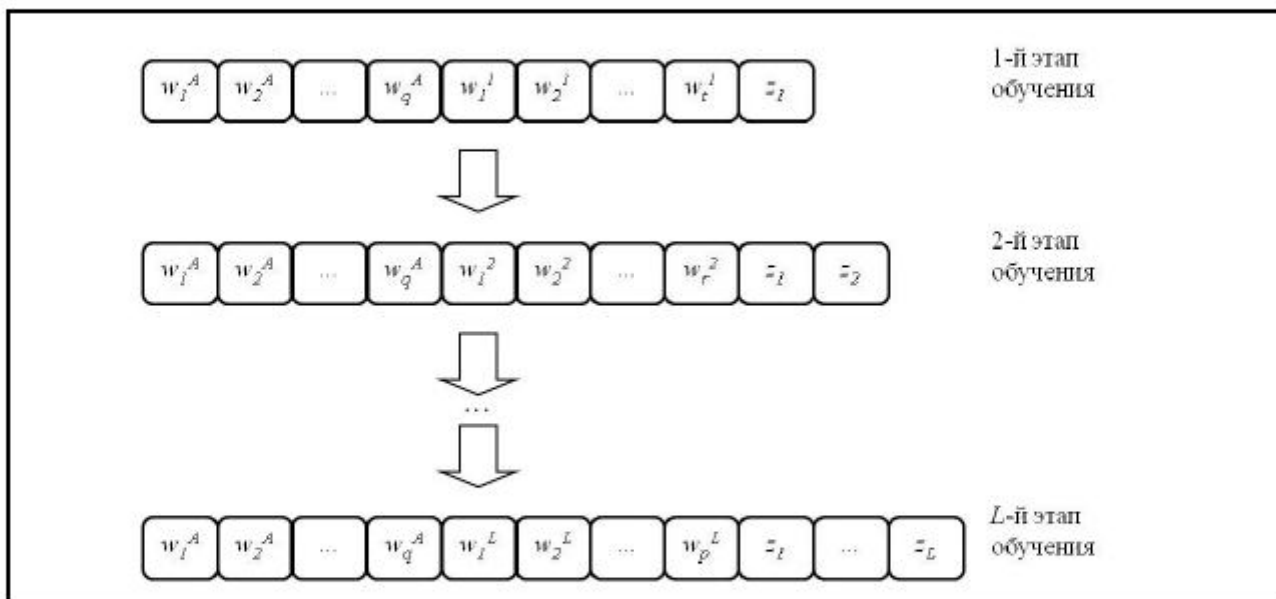


Рис. 4. Изменения структур хромосом при обучении при помощи генетических алгоритмов

5. Снопальников В.А., Григорьев С.Н. Надежность и диагностика технологических систем: учебник. -М.: Высшая школа, 2005. – 343 с.

6. Коновалова Т.В. Выбор входных параметров для построения модели процесса резания на основе нейронных сетей // Вісник Сумського державного університету. (Серія Технічні науки). 2005. № 11(83). С. 84-89.

7. Киселев С.А., Григорьев А.С., Геранюшкин А.В., Пушков Р.Л. Прогнозирование стойкости инструмента при чистовой обработке // Вестник МГТУ «Станкин». 2008. №4(4). С. 23–32.

8. Dimla D. E., Lister P. M. On-line metal cutting tool condition monitoring. I: force and vibration analyses // International Journal of Machine Tools and Manufacture. 2000. Vol. 40 (5). p. 739–768.

9. Tanikic D., Manic M., Radenkovic G., Mancic D. Metal cutting process parameters modeling: an artificial intelligence approach // Journal of Scientific & Industrial Research. 2009. Vol. 68. p. 530-539.

10. Сидоров А.С. Мониторинг и прогнозирование износа режущего инструмента в мехатронных станочных системах. Автореф. дисс. канд. техн. наук: 05.13.06. – Уфа: УГАТУ, 2007. – 16с.

11. Кабак И.С., Суханова Н.В. Доменная нейронная сеть. Патент на полезную модель № 72084 от 03.12.2007.

12. Степанов С.Ю., Кабак И.С. Алгоритмы фрагментации больших нейронных сетей и исследование его сходимости // Информационные технологии. 2012. № 7. С. 73-78.

Кабак Илья Самуилович – канд. техн. наук, профессор кафедры компьютерных систем управления МГТУ «СТАНКИН».

Тел.: (903) 660-59-71. E-mail: ikabak@mail.ru

Суханова Наталья Вячеславовна - канд. техн. наук, доцент кафедры компьютерных систем управления МГТУ «СТАНКИН».

Тел.: (963) 723-81-62. E-mail: n_v_sukhanova@mail.ru

Гаделев Асхат Мунирович – аспирант кафедры компьютерных систем управления МГТУ «СТАНКИН».

Тел.: (926) 691-16-86. E-mail: agadelev@mail.ru

Kabak Ilia Samuilovich – candidate of Science in engineering, full professor of sub-department «Computer control systems» of MSTU «STANKIN».

Tel: (903) 660-59-71. E-mail: ikabak@mail.ru

Suhanova Natalia Viacheslavovna – candidate of Science in engineering, associate professor of sub-department «Computer control systems» of MSTU «STANKIN».

Tel: (963) 723-81-62. E-mail: n_v_sukhanova@mail.ru

Gadelev Askhat Munirovich – postgraduate student of sub-department «Computer control systems» of MSTU «STANKIN».

Tel: (926) 691-16-86. E-mail: agadelev@mail.ru